

EVALUAREA RISCULUI UNUI PORTOFOLIU DE ACȚIUNI UTILIZÂND METODA VALUE AT RISK

Căpățînă Adrian-Nicolae^{1*}

Academia de Studii Economice din București, România.

Rezumat

Prezenta lucrare are ca scop evaluarea riscului pentru un portofoliu de acțiuni folosind metoda Value-at-Risk, fiind de interes atât pentru instituțiile financiare, cât și pentru posibili investitori individuali. Folosind randamentele zilnice ale portofoliului pe o perioadă de 2 ani, se va estima volatilitatea acestuia cu diverse specificații ale modelelor GARCH (GARCH, IGARCH, EGARCH, TGARCH) și distribuții ale erorilor normale, t-sudent și GED. Ulterior se va identifica modelul optim de estimare a volatilității necesare în calculul VaR folosind metoda backtesting.

Cuvinte-cheie: Value at Risk, volatilitate, GARCH, backtesting, portofoliu, acțiuni

Clasificare JEL: G11, C52, C53

Introducere

În contextul recentelor schimbări din economie, principalul obiectiv al corporațiilor, fondurilor de investiții, băncilor și, în general, oricăror organizații care urmăresc profituri a devenit managementul riscului. Efectele generate de criza financiară au fost un semnal de alarmă și pentru autorități, care au adoptat o serie de reglementări suplimentare cu privire la cerințele minime de capital. Din acest motiv, instituțiile financiare sunt interesate să afle cu ce riscuri se pot confrunta și cum pot fi acestea evaluate cât mai corect.

Cea mai comună metodă statistică pentru cuantificarea riscului de piață este Value at Risk (VaR). Acesta este un indicator probabilistic care măsoară pierderea maximă a valorii de piață a unui portofoliu, care poate să apară într-o anumită perioadă de timp, luându-se în considerare un nivel de încredere prestabilit. Deoarece o supraevaluare sau chiar o subestimare a riscului poate provoca pierderi unei companii sau oricărui investitor, de-a lungul timpului, s-au dezvoltat mai multe modele de calcul pentru a surprinde cât mai bine riscul real. Numeroase lucrări științifice au abordat această problemă încercând identificarea unui model care să ofere o acuratețe ridicată în evaluarea riscului.

Scopul acestei lucrări este evaluarea riscului pentru un portofoliu de acțiuni pe o perioadă de 2 ani. În primul capitol voi prezenta stadiul actual al cunoașterii cu privire la metodele VaR făcând referire la articolele științifice studiate. În al doilea capitol, voi prezenta metodele folosite pentru evaluarea riscului și caracteristicile serilor de dat (testarea

* Autor de contact, Căpățînă Adrian Nicolae - capatina.adrian23@yahoo.ro

stationarității, testarea apariției fenomenului de *volatility clustering* și testarea a autocorelării), justificând folosirea modelelor GARCH pentru estimarea volatilității. În capitolul 3 sunt prezentate rezultatele empirice ale cercetării. Am estimat volatilitatea pentru întreg portofoliul folosind diferite metode analitice, urmând să calculez Value at Risk pentru un orizont de 10 zile și folosind anumite intervale de încredere (95% și 99%). În final voi identifica modelul optim pentru calculul VaR prin aplicarea backtesting-ului. Rezultatele obținute pot prezenta interes atât pentru societățile de investiții, cât și pentru investitori individuali.

1. Recenzia literaturii științifice

1.1 Măsura Value-at-Risk

Riscul reprezintă modificarea valorii dintre două momente de timp, mai exact variabilitatea unei valori prezente în viitor (Artzner, 1999). Metoda cea mai folosită pentru evaluarea riscului este Value at Risk, introdusă pentru prima dată de către departamentul de risc din cadrul băncii de investiții J.P. Morgan în 1994. Value at Risk este o măsură simplă care încearcă să transpună într-un singur număr valoarea riscului unui portofoliu de active financiare. În scurt timp metoda a ajuns să fie folosită de instituțiile financiare, dar mai ales de către fondurile de investiții. De asemenea, Comitetul de Supraveghere Bancară al Băncii Reglementelor Internaționale folosește această metodă pentru a calcula cerințele minime de capital pentru bănci (Iorgulescu, 2007).

În practică există trei metode clasice pentru calculul VaR: metoda simulării istorice, simularea Monte Carlo și metoda analitică. Datorită importanței de a cunoaște o valoare cât mai corectă a riscului s-au dezvoltat mai multe metode “hybrid”, metodele clasice reprezentând baza acestora.

Metoda simulării istorice este utilizată pe scară largă în practică. Aceasta asumă faptul că viitorul apropiat este o proiecție a trecutului. Principalul avantaj este ușurința cu care este pus în aplicare. Nu există parametri care trebuie estimați și nu trebuie efectuată nicio optimizare numerică. Datele din trecut redau pe deplin distribuția rezultatelor viitoare fără a se impune vreo ipoteză suplimentară. Totuși, metoda simulării istorice pentru calculul VaR reacționează prea lent la schimbările de pe piață și poate ignora grupările de variație (*volatility clustering*)¹.

Simularea Monte Carlo presupune specificarea unui proces stocastic pentru factorii de risc ai portofoliului. Avantajul acestei metode este că poate captura o varietate mare de comportamente ale pieței, mai exact atât riscul inclus în scenarii care nu presupun modificări extreme ale pieței, cât și informații despre impactul scenariilor extreme (Codîrlășu, 2007). Dezavantajul acestei metode este timpul și costul necesar implementării, dar și riscul de model în cazul în care procesul stocastic a fost ales necorespunzător (Stan G., 2015).

Metoda analitică este cea mai simplă și ușor de implementat, acesta având la bază ipoteza că randamentul portofoliului este normal distribuit de mediu μ și deviație standard σ , $R \sim N(\mu, \sigma)$. Pentru calculul VaR prin această metodă este necesară estimarea parametrilor pe baza datelor istorice (volatilitate, coeficienți de corelație, randamente medii). De asemenea, pentru cazul în care un portofoliu conține mai multe tipuri de instrumente financiare, se estimează volatilitatea și se calculează riscul pentru fiecare categorie de

¹ Christoffersen (2012) – “*Elements of financial risk management*”

instrumente financiare. Principalul dezavantaj al acestei metode este exact ipoteza pe care se bazează. Studiile empirice au arătat că în practică rar se întâmplă ca evoluția prețului unui activ urmează o distribuție normală.² Cu toate acestea, metoda simulării istorice și metoda simulării Monte Carlo, denumite și metode non-parametrice, au raportat performanțe mai slabe în comparație cu metodele parametrice. (Poon & Granger, 2003).

Totuși, aceste metode sunt folosite de cele mai multe ori în funcție de tipul instrumentelor financiare, neexistând o metodă care să ofere rezultate la fel de bune pentru toate categoriile de instrumente financiare. De obicei, în cadrul societăților de investiții, evaluarea VaR presupune împărțirea portofoliului în mai multe clase de instrumente, iar pentru fiecare clasă se proiectează un algoritm de calcul și se adaptează un model de calcul pentru VaR. De exemplu, în cadrul Societății de Investiții Financiare Banat-Crișana (SIF 1), se folosesc următoarele metode de calcul³:

- Metoda analitică (varianță-covarianță) – pentru acțiuni lichide tranzacționate la BVB;
- Metoda simulării Monte-Carlo – pentru acțiuni nelichide tranzacționate la BVB, acțiuni nelistate, obligațiuni, titluri de stat, depozite și certificate de depozit.

O alternativă la măsurarea riscului prin metoda VaR, frecvent utilizată de managerii de risc, este Expected Shortfall. ES corectează câteva deficiențe ale metodei VaR, luând în considerare pierderea portofoliului peste nivelul de încredere. De asemenea, ia în considerare proprietatea de subaditivitate. În plus, prin utilizarea aceste metode se diminuează impactul deciziei privind alegerea nivelului de încredere. (Trenca et al, 2015). Artzner (1999) definește în lucrarea sa noțiunea de măsură coerentă a riscului și arată că ES este o măsură coerentă a riscului în comparație cu VaR.

1.2. Modelarea volatilității portofoliului

Cea mai importantă etapă în calculul valorii la risc o reprezintă estimarea volatilității. Acest lucru a trezit interes multor cercetători și practicieni ai piețelor financiare. Ca rezultat, un număr foarte mare de modele au fost dezvoltate începând cu modelul econometric ARCH (Autoregressive conditional heteroskedasticity), propus de Engle în 1982 și generalizat de Bollerslev în 1986 (Generalized ARCH). Modelul GARCH este mult mai ușor de implementat în comparație cu modelul ARCH, care necesită un număr ridicat de parametri pentru a surprinde varianța condiționată. De asemenea, studiile empirice au demonstrat faptul că modelul GARCH are rezultate mai bune decât modelul original.

Datorită faptului că ambele modele au un dezavantaj foarte important, acela că prezintă un efect simetric al seriei rezidurilor pătratice asupra variației condiționate, au fost dezvoltate numeroase modele care să permită studierea caraterului asimetric. Printre cele mai cunoscute se numără modelul IGARCH introdus de Taylor în 1986, modelul EGARCH introdus de Nelson în 1991, modelul A-PARCH propus de Ding, Granger și Engle în 1993, modelul TGARCH propus de Zakoian în 1994⁴.

² Codirlaşu (2007) – “*Modele Value at Risk*”

³ Manațe D. et al. (2006) – “*Aspecte privind managementul riscului în societățile de investiții financiare, în contextul schimbărilor economice recente*”

⁴ Hansen, Lunde (2001) – “*A comparison of volatility models: Does Anything Beat a GARCH(1,1)?*”

Un alt model pentru estimarea volatilității, care nu face parte din “universul GARCH”, este modelul EWMA (exponentially weighted moving average) introdus de RiskMetrics în 1996 sugerând că este mult mai satisfăcătoare, deoarece include mult mai bine șocurile apărute la un moment dat în piață.

Una dintre cele mai relevante studii făcute cu privire la estimarea volatilității este cel realizat de Hansen și Lunde în 2001. Aceștia compară 330 de modele diferite de estimare a volatilității aplicate pe rata de schimb dintre dolar și moneda germană, dar și pe acțiunea IBM. În cazul ratei de schimb modelul GARCH(2,2) a fost superior celorlalte modele mai avansate, pe când în cazul acțiunii IBM, modelul A-PARCH(2,2) s-a comportat cel mai bine.

Un alt articol de referință pentru estimarea volatilității este cel realizat de Poon și Granger în 2003 unde sunt comparate 93 de studii care au ca obiectiv estimarea volatilității. Aceștia împart metodele în 4 categorii:

- HISVOL (historical volatility) - unde sunt incluse toate metodele bazate pe volatilitatea istorică;
- GARCH – unde este inclus orice model derivat din modelele ARCH-GARCH;
- ISD (implied standard deviation) – reprezentând volatilitatea implicită perfect explicată de prețul opțiunii în contextul modelului Black-Scholes;
- SV (stochastic volatility) – modele în care volatilitatea este estimată printr-un proces stocastic.

Dintre cele 4 categorii, modelele ISD au obținut cele mai bune estimări, însă numărul studiilor în care a fost inclus acest model nu este destul de relevant, deoarece modelul nu poate fi utilizat pentru toate activele. Comparând metodele HISVOL și GARCH, fiind cele mai utilizate, rezultatul a fost puțin în favoarea volatilității istorice. Dintre cele 93 de studii, 17 au fost comparații între versiuni ale modelelor GARCH unde modelul ARCH este clar dominat, iar modelele care au incorporat volatilitatea asimetrică ca EGARCH sau GJR-GARCH au performat mai bine decât GARCH.

Într-un alt studiu (Trenca et al, 2015) se determină pierderea posibilă a unui portofoliu de valute utilizând metodele VaR și ES. Pentru calculul VaR se folosesc metodele EVT, GARCH, EGARCH, TARCH și GARCH pe diferite perioade (structural breaks), cel din urmă oferind cele mai bune rezultate. De asemenea, s-a calculat și pierderea maximă posibilă în cazul în care nivelul de încredere este depășit. Rezultatele privind calculul VaR și ES au arătat că pierderile portofoliului pot fi determinate de creșterea volatilității pieței.

Totuși, nu toate studiile privind metodele parametrice pentru calculul VaR au înclinat în favoarea modelelor GARCH. De exemplu, din rezultatele lui Codirlaşu (2007), modelul EWMA a performat cel mai bine. Comparația a fost realizată pe un portofoliu format din 4 acțiuni tranzacționate la Bursa de Valori din București. De asemenea, metodele GARCH s-au încadrat și ele în nivelul de relevanță de 1% având avantajul că acestea implică cerințe de capital inferioare.

2. Metodologia cercetării

Scopul acestei cercetări, așa cum reiese și din titlu, este evaluarea sau analiza riscului unui portofoliu de active financiare, mai exact de acțiuni. Pentru a reuși acest lucru voi folosi metoda cea mai utilizată în evaluarea riscului, și anume **Value-at-Risk** introdusă de J.P Morgan în 1994. De-a lungul timpului, au fost concepute mai multe

modalități pentru această măsură. În această lucrare, voi calcula VaR analitic folosind următoarea formulă:

$$VaR = S_0 Q_{1-\alpha} \sigma \sqrt{N} \quad (1)$$

unde s_0 reprezintă valoarea portofoliului în momentul calculării, $Q_{1-\alpha}$ reprezintă cantila distribuției normale pentru intervalul de încredere $1-\alpha$, σ este volatilitatea zilnică a portofoliului, iar N este perioada pentru care se realizează calculul. Pentru acest studiu voi calcula VaR folosind intervalele de încredere 95% și 99% pentru 10 zile, considerând valoarea portofoliului 1 USD.

În vederea estimării varianței necesare pentru calculul VaR am testat diferite modele folosind programul Eviews 7:

• **GARCH (Generalized Autoregressive Conditional Heteroskedasticity)**⁵ – modelul este o generalizare a modelului ARCH introdus de Engle în 1982 și este scris astfel:

$$\sigma_{t+1}^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_t^2 + \sum_{j=1}^q \beta_j \sigma_t^2 \quad (2)$$

unde cei doi coeficienți α și β denotă persistența modelului, iar suma lor trebuie să fie mai mică de 1, în caz contrar vom avea volatilitate explozivă. Constanta ω reprezintă media pe termen lung a varianței și împreună cu ceilalți coeficienți trebuie să fie pozitivi. Prin urmare, modelul GARCH presupune că varianța condițională urmează un proces predictibil și depinde de ultimele știri, șocuri din piață, dar și de varianța condițională anterioară. De altfel, modelul acceptă și fenomenul de *volatility clustering* care denotă faptul că modificările mari ale randamentelor unui activ sunt urmate de modificări mari, iar randamentele mici sunt urmate de randamente mici.

Datorită faptului că modelul GARCH nu surprinde asimetria impactului randamentului cursului activelor financiare, dar și pentru a relaxa anumite ipoteze, au fost dezvoltate o serie de modele numite și extensii ale modelului GARCH⁶:

• **IGARCH (Integrated GARCH)** – modelul presupune eliminarea mediei pe termen lung a varianței din ecuație, fiind scris astfel:

$$\sigma_{t+1}^2 = \sum_{i=1}^p \alpha_i \epsilon_t^2 + \sum_{j=1}^q \beta_j \sigma_t^2 \quad (3)$$

unde suma coeficienților α și β este 1. Respectând această condiție, Engle și Bollerslev numesc acest model GARCH intergrat.

Având în vedere faptul că, pentru acțiuni, mișcările în jos ale pieței sunt urmate de o volatilitate mai mare decât mișcările în sens crescător de aceeași amplitudine, au fost dezvoltate o serie de modele care să surprindă asimetria:

• **TGARCH (Threshold GARCH)** – modelul introdus de Zakoian în 1990 are următoarea specificație pentru ecuația varianței:

$$\sigma_{t+1}^2 = \omega + \sum_{i=1}^p \alpha_i \epsilon_t^2 + \sum_{j=1}^q \beta_j \sigma_t^2 + \sum_{k=1}^r \gamma_k \epsilon_t^2 d_t \quad (4)$$

⁵ Bollerslev T. (1986) – "Generalized Autoregressive Conditional Heteroskedasticity"

⁶ Codirlaşu A. (2007) – "Modele Value at Risk"

unde $d = 1$, dacă $\varepsilon < 0$ și $d = 0$, dacă $\varepsilon > 0$. În acest fel veștile rele ($\varepsilon < 0$) au un impact mai ridicat asupra varianței ($\alpha + \gamma$). Dacă $\gamma \neq 0$, atunci factorii care influențează varianța au un impact asimetric.

• **EGARCH (Exponential GARCH)** – model propus de Nelson în 1991 și are următoarea specificație pentru ecuația varianței:

$$\log(\sigma_{t+1}^2) = \omega + \sum_{i=1}^p \alpha_i \frac{\varepsilon_t}{\sigma_t} + \sum_{j=1}^q \beta_j \log(\sigma_t^2) + \sum_{k=1}^r \gamma_k \frac{\varepsilon_t}{\sigma_t} \quad (5)$$

unde termenul din stânga este logaritmul varianței condiționate. Acest lucru implică faptul că efectul informațiilor este exponențial (și nu pătratic) iar varianța prognozată va fi obligatoriu pozitivă. La fel ca în cazul *TARCH*, impactul informațiilor este asimetric dacă $\gamma \neq 0$.

2.1. Setul de date

Pentru a realiza această cercetare, am presupus un portofoliu simplu cu valoarea 1 RON format din 3 acțiuni tranzacționabile la Bursa de Valori București: Banca Transilvania (TLV), OMV Petrom (SNP) și Transelectrica (TEL). Acțiunile au o pondere egală în portofoliu și au fost selectate după următoarele criterii:

- toate cele trei acțiuni fac parte din indicele BET ce reflectă evoluția celor mai tranzacționate companii de pe piața reglementată a BVB, exclusiv societățile de investiții financiare (SIF-uri), însemnând că sunt foarte atractive și au o lichiditate ridicată;
- fiecare companie reprezintă un sector diferit de activitate (Banca Transilvania – financiar-bancar, OMV Petrom – industria petrolieră, Transelectrica – industria energetică), ceea ce conduce la o bună diversificare a portofoliului.

Pentru analiza și evaluarea riscului portofoliului am folosit prețurile zilnice de închidere din perioada 22.09.2015 – 22.09.2017. Datele au fost obținute de pe www.tranzactiibursiere.ro.

Pentru a obține rentabilitățile zilnice pentru fiecare acțiune și pentru întreg portofoliu am prelucrat seriile de date în Excel prin aplicare de logaritmi obținând 502 observații. În tabelul nr. 1 sunt prezentate statisticile descriptive ale rentabilităților zilnice pentru cele 3 acțiuni și portofoliu.

Tabel nr.1. Statistici descriptive randamente TLV, SNP, TEL, portofoliu

	TLV	SNP	TEL	PORTOFOLIU
Medie	- 0.000169	- 0.000374	0.000193	-0.000117
Mediană	0.00000 0	0.000000	0.000000	
Maxim	0.05849 6	0.061301	0.058841	0.040330
Minim	- 0.301344	- 0.080689	- 0.075035	-0.093703
St.dev.	0.02024 7	0.014823	0.011883	0.010765
Skewness	- 7.554966	- 0.086912	- 0.708014	-1.678204

Kurtosis	107.384 5	5.929953	11.66547	16.61354
-----------------	--------------	----------	----------	----------

Sursa: Prelucrare proprie Eviews

Indicatorul Skewness folosit în analiza distribuției unei serii de date pentru a indica deviația în raport cu o distribuție simetrică în jurul mediei ne indică faptul că, în cazul rentabilităților celor 3 acțiuni, distribuția este înclinată spre dreapta, având mai multe valori extreme spre stânga.

Indicatorul Kurtosis folosit în analiza distribuției unei serii de date pentru a indica gradul de aplatizare sau de ascuțire, fiind mai mare decât 3 pentru fiecare dintre acțiuni, inclusiv portofoliu, ne indică faptul că rentabilitățile zilnice au o distribuție leptokurtotică, având mai multe valori concentrate în jurul mediei și cozi mai groase ceea ce înseamnă probabilități ridicate pentru valori extreme.

Caracteristicile randamentelor portofoliului

Înainte de a utiliza modelele pentru estimarea varianței necesare în calculul VaR, trebuie să analizăm seria de randamente zilnice ale portofoliului cu privire la următoarele caracteristici: staționaritate, distribuție leptokurtotică, clusterizare a volatilității și autocorelație.

Pentru testarea staționarității seriei de randamente am folosit testul Augmented Dickey-Fuller. Am testat ipoteza nulă de nestacionaritate atât în cazul specificației trend și intercept. Rezultatele sunt prezentate în figura 1.

	t-Statistic	Prob .*
Augmented Dickey-Fuller test statistic	-	0.000
Test critical values:		
1% level	21.86185	0
5% level	-	
10% level	3.976480	
	3.418816	
	-	
	3.131943	

Figura nr.1. Testarea staționarității

Sursa: Prelucrare proprie Eviews

Conform rezultatelor, probabilitatea asociată testului ADF se află sub nivelul de relevanță de 1%, deci putem respinge ipoteza nulă și concluziona că seria este staționară, media și varianța seriei este constantă în timp.

Pentru testarea normalității distribuției serie de randamente am folosit în Eviews testul Jarque-Bera. În figura 2 sunt prezentate rezultatele testului Jarque-Bera, cât și statisticile descriptive pentru seria de randamente ale portofoliului.




Figura nr.2. Testarea normalității distribuției

Sursa: Prelucrare proprie Eviews

Rezultatele obținute în urma testului Jarque-Bera indică faptul că distribuția randamentelor portofoliului nu este distribuită normal, probabilitatea asociată acestuia fiind 0. Indicatorul Skewness este negativ indicând faptul că distribuția este puțin înclinată spre dreapta cu mai multe valori extreme spre stânga. Acest lucru se traduce prin faptul că știrile negative au un impact mai mare decât asupra volatilității decât cele pozitive. Indicatorul Kurtosis este mai mare decât 3 ceea ce indică o distribuție leptokurtotică, existând o probabilitate ridicată să se atingă valori extreme. Dacă am fi presupus că randamentele zilnice au o distribuție normală, rezultatul ar fi fost o subestimare a riscului. Totuși non-normalitatea distribuției ne sugerează faptul că folosirea cuantilelor distribuție normale în calculul VaR va subestima riscul.

Fenomenul de *volatility clustering* se manifestă atunci când modificările semnificative ale randamentelor sunt urmate de modificări la fel de mari, iar modificările nesemnificative sunt urmate de modificări reduse. Utilizând metoda grafică (figura 3) se poate observa grupări de varianță în seria randamentelor portofoliului. Acest lucru ne sugerează că este bine să folosim pentru calculul VaR modele de varianță condiționată ca GARCH.




Figura nr.3. Evoluția randamentelor portofoliului

Sursa: Prelucrare proprie Eviews

Testarea independenței seriale se realizează prin funcția de autocorelare (ACF) și funcția de autocorelare parțială (PACF). Figura 4 prezintă corelograma seriei randamentelor estimată până la lag-ul 10.

Sample: 9/22/2015 9/22/2017
Included observations: 502









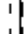



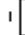




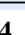

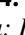
Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.021	0.021	0.2126	0.645
		2	-0.061	-0.061	2.0781	0.354
		3	-0.052	-0.050	3.4629	0.326
		4	-0.022	-0.023	3.7003	0.448
		5	0.004	-0.001	3.7081	0.592
		6	0.010	0.004	3.7564	0.710
		7	0.019	0.017	3.9464	0.786
		8	0.088	0.089	7.9298	0.440
		9	0.006	0.006	7.9493	0.539
		10	0.050	0.064	9.2412	0.509

Figura nr.4. Corelograma randamentelor

Sursa: Prelucrare proprie Eviews

Din corelograma randamentelor se poate observa că probabilitatea aferentă fiecărui lag este peste nivelul critic de 5%, implicând astfel că seria nu prezintă autocorelare.

Ținând cont de staționaritatea seriei, de clusterizarea volatilității, dar și de distribuția leptokurtotică a randamentelor portofoliului ne sugerează că măsurile VaR calculate în ipoteza normalității tind să subestimeze riscul. În această situație se justifică utilizarea modelelor de varianță condiționată GARCH.

3. Rezultate și discuții

În literatura de specialitate, problema volatilității a fost abordată fără a se ajunge la concluzia că existe un model care să ofere cele mai bune rezultate de fiecare dată când sunt utilizate. De aceea este recomandată testarea mai multor modele în funcție de caracteristicile serilor de date. Pentru o bună analiză a măsurilor de risc elaborate în acest studiu am folosit modelele de volatilitate condiționată, mai exact modelele GARCH, ținând cont și de rezultatele obținute anterior.

3.1. Modelarea volatilității portofoliului

Modelul **GARCH(p,q)** este o generalizare a modelului ARCH propus de Engle în 1982. Acest model presupune că varianța condițională urmează un proces predictibil și depinde de ultimele știri, șocuri din piață, dar și de varianța condițională anterioară. Pentru început am considerat modelul simplu GARCH(1,1) urmând să estimez și modelule cu p și q cuprinși între 1 și 3. De asemenea, pentru fiecare model am considerat 3 distribuții ale erorilor: normală, t-student și GED. Diferențierea modelelor validate a fost făcută cu ajutorul criteriilor informaționale *Akaike info criterion* și *Schwarz criterion* (acesta fiind prioritar, deoarece este relevant să penalizeze mai mult pierderea gradelor de libertate la adăugarea unor parametri) sintetizate în tabelul nr. 2.

Tabel nr.2. Criterii informaționale pentru modelele GARCH

Model	Akaike criterion	Schwarz criterion
GARCH(1,1)-N	-6.252312	-6.227102
GARCH(1,1)-T	-6.554641	-6.521026
GARCH(1,3)-T	-6.552452	-6.502030
GARCH(3,3)-T	-6.552597	-6.485368
GARCH(1,1)- GED	-6.517749	-6.484134
GARCH(1,3)- GED	-6.513988	-6.463567

Sursa: Prelucrare proprie Eviews

În urma aplicării modelelor GARCH, am selectat doar modelele valide (coeficienți semnificativi diferiți de 0), iar modelul ales în urma minimizării criteriilor informaționale este GARCH(1,1) cu distribuția erorilor t-student. Asupra acestui model am aplicat cele 3 teste: corelograma rezidurilor pătrate, testul ARCH-LM și testul de normalitate. Din cele 3 teste a rezultat că rezidurile modelului nu prezintă autocorelare, sunt homoskedastice și nu sunt distribuite normal.

Prin urmare, pentru estimarea volatilității vom folosi coeficienții modelului GARCH(1,1) cu distribuția t-student a erorilor prezentați în tabelul nr. 3, iar în figura 5 se poate observa graficul volatilității estimate.

Tabel nr. 3. Coeficienții estimați pentru modelul GARCH(1,1)-T

Model	GARCH(1,1)-T
ω	2.24E-05
α	0.242
β	0.621
$\alpha+\beta$	0.863

Sursa: Prelucrare proprie Eviews

Coeficienții îndeplinesc condițiile modelului GARCH, suma lor fiind mai mică decât 1. Coeficientul α arată cât de repede se ajustează volatilitatea în funcție de informațiile din piață, iar β face referire la persistența volatilității.

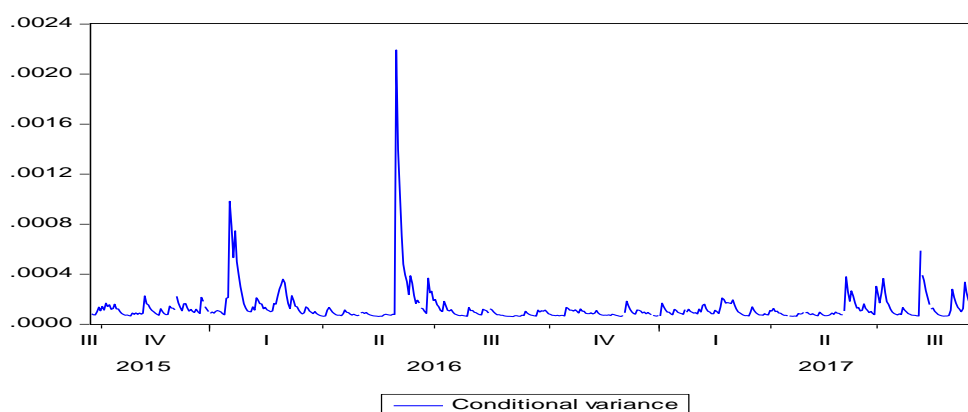


Figura nr.5. Volatilitatea GARCH(1,1)-T a portofoliului

Sursa: Prelucrare proprie Eviews

Pentru că suma coeficienților α și β este apropiată de 1 în cazul modelului GARCH(1,1), am modelat volatilitatea cu ajutorul modelului **IGARCH**. Acest model elimină volatilitatea pe termen lung din ecuație, impunându-se condiția ca suma coeficienților să fie 1. La fel ca la modelul GARCH am folosit p și q cu valori între 1 și 3 sub fiecare dintre distribuțiile erorilor. Modelul optim a fost ales în urma minimizării criteriilor informaționale AIC și SBIC prezentate în tabelul nr. 4.

Tabel nr.4. Criterii informaționale pentru modelele IGARCH

Model	Akaike criterion	Schwarz criterion
IGARCH(1,1)-N	-6.169534	-6.161130
IGARCH(1,3)-N	-6.260742	-6.235532
IGARCH(2,1)-N	-6.177412	-6.160605
IGARCH(2,2)-N	-6.196925	-6.171715
IGARCH(2,3)-N	-6.200472	-6.166857
IGARCH(1,1)-T	-6.512778	-6.495971
IGARCH(2,2)-T	-6.541100	-6.507486
IGARCH(1,1)-GED	-6.470411	-6.453604
IGARCH(2,1)-GED	-6.474671	-6.449460
IGARCH(2,2)-GED	-6.500323	-6.466708

Sursa: Prelucrare proprie Eviews

Selectând doar modelele valide în care coeficienții sunt semnificativi statistic, am ales modelul optim IGARCH(2,2) sub distribuția erorilor t-student folosind criteriile informaționale. Asupra rezidurilor modelului am aplicat testul autocorelării, testul ARCH-LM și testul Jarque-Bera pentru normalitate. În urma rezultatelor, rezidurile modelului nu prezintă autocorelare, sunt homoscedastice și au o distribuție leptokurtotică. Prin urmare, pentru estimarea volatilității voi folosi coeficienții prezentați în tabelul nr.5, iar în figura nr. 6 se poate observa graficul volatilității estimate.

Tabelul nr.5. Coeficienții estimați pentru modelul IGARCH(2,2)-T

Model	IGARCH(2,2)-T
α_1	0.146
α_2	-0.146
β_1	1.673
β_2	-0.673
$\alpha_1 + \alpha_2 + \beta_1 + \beta_2$	1

Sursa: Prelucrare proprie Eviews

Coeficienții îndeplinesc condițiile modelului IGARCH, suma lor fiind egală cu 1. Media pe termen lung a volatilității este eliminată în cadrul acestui model. Respectând condițiile putem estima volatilitatea cu ajutorul acestui model.




Figura nr.6. Volatilitatea IGARCH(2,2)-T a portofoliului

Sursa: Prelucrare proprie Eviews

Modelele GARCH și IGARCH nu surprind asimetria, acesta fiind specifică de obicei acțiunilor. Din acest motiv am ales să estimez volatilitatea portofoliului folosind modelul TGARCH. Pentru identificarea modelului optim am estimat modele folosind p, q și r între 1 și 2.


În urma estimării volatilității cu ajutorul modelelor TGARCH, un singur model a fost validat având coeficienții semnificativ statistic și anume modelul TGARCH(1,1,1) sub distribuția normală a erorilor. Asupra rezidurilor modelului am aplicat testul autocorelării, testul ARCH-LM și testul Jarque-Bera pentru normalitate. În urma rezultatelor, rezidurile modelului nu prezintă autocorelare, sunt homoscedastice și au o distribuție leptokurtotică. Prin urmare, pentru estimarea volatilității voi folosi coeficienții prezentați în tabelul nr. 6, iar în figura nr. 7 se poate observa graficul volatilității estimate.

Tabelul nr.6. Coeficienții estimați pentru modelul TGARCH(1,1,1)-N

Model	TGARCH(1,1,1)-N
ω	0.000222
α	-0.043483
β	0.042469
γ	-0.916711

Sursa: Prelucrare proprie Eviews

Se poate observa că γ este diferit de 0, ceea ce înseamnă că factorii care influențează varianța au un impact asimetric. Îndeplinind condițiile putem estima volatilitatea folosind acest model.

**Figura nr.7. Volatilitatea TGARCH(1,1,1)-N a portofoliului**

Sursa: Prelucrare proprie Eviews

Un alt model des utilizat care surprinde asimetria șocurilor din piață este modelul **EGARCH**. Am estimat volatilitatea utilizând acest model cu p , q și r între 1 și 2, minimizând criteriile informaționale prezentate în tabelul nr. 7.

Tabel nr.7. Criterii informaționale pentru modelele EGARCH

Model	Akaike criterion	Schwarz criterion
EGARCH(1,2,1)-N	-6.257789	-6.215771
EGARCH(2,1,1)-N	-6.263696	-6.221678
EGARCH(2,2,1)-N	-6.278683	-6.228262

Sursa: Prelucrare proprie Eviews

Selectând doar modelele valide în care coeficienții sunt semnificativi statistic, am ales modelul optim EGARCH(2,2,1) sub distribuția normală a erorilor folosind criteriile informaționale. Asupra rezidurilor modelului am aplicat testul autocorelării, testul ARCH-LM și testul Jarque-Bera pentru normalitate.

În urma rezultatelor, rezidurile modelului nu prezintă autocorelare, sunt homoscedastice și au o distribuție leptokurtotică. Prin urmare, pentru estimarea volatilității voi folosi coeficienții prezentați în tabelul nr. 8, iar în figura nr.8 se poate observa graficul volatilității estimate.

Tabel nr.8. Coeficienții estimați pentru modelul EGARCH(2,2,1)-N

Model	EGARCH(2,2,1)-N
ω	-10.44632
α_1	0.169820
α_2	0.216881
β_1	0.151815
β_2	0.643717
γ	-0.757991

Sursa: Prelucrare proprie Eviews

Coeficienții prezentați sunt utilizați pentru estimarea logaritmului varianței condiționate. Acest lucru implică faptul că efectul informațiilor este exponențial și nu pătratic. Îndeplinind condițiile putem estima volatilitatea folosind acest model.

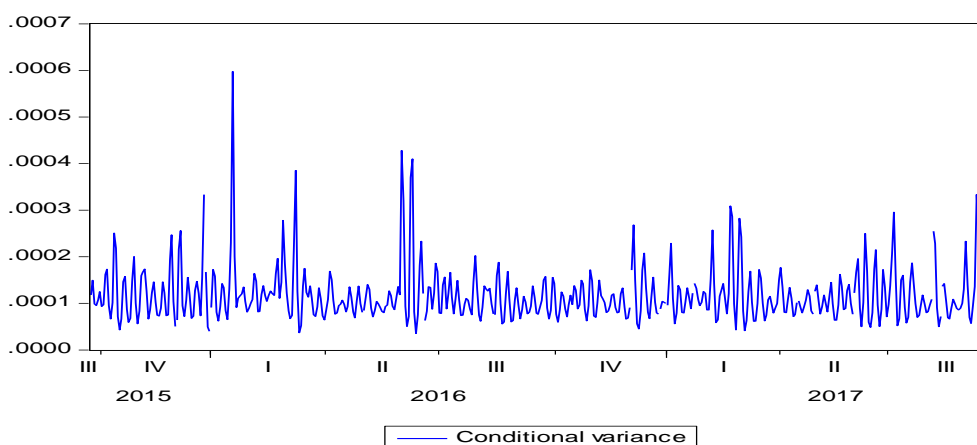


Figura nr.8. Volatilitatea EGARCH(2,2,1)-N a portofoliului

Sursa: Prelucrare proprie Eviews

3.2. Evaluarea riscului portofoliului

Cu ajutorul fiecărui model optim selectat am estimat volatilitatea portofoliului necesară pentru evaluarea riscului. Am considerat un orizont de 10 zile (în cazul nostru 06.10.2017) cu probabilități de 95% și 99% pentru calculul Value at Risk. Volatilitatea pentru un orizont de 10 zile a fost calculată ca radical din suma varianțelor estimate în Eviews la momentele $t+1, t+2, \dots, t+10$. Ulterior am introdus datele în Excel pentru calculul VaR. Rezultatele sunt prezentate în tabelul nr. 9.

Tabel nr. 9. Calculul VaR

Model	Volatilitatea 10 zile	VaR-95%	VaR-99%
GARCH(1,1)-T	0.03522783	5.794%	8.195%
IGARCH(2,2)-T	0.057911546	9.526%	13.472%
TGARCH(1,1,1)-N	0.03391165	5.578%	7.889%
EGARCH(2,2,1)-N	0.071565449	11.771%	16.649%

Sursa: Prelucrare proprie Excel

Se poate observa că Value-at-Risk are valoarea cea mai mică utilizând modelul TGARCH(1,1,1) sub distribuția normală a erorilor pentru estimarea volatilității, iar valoarea cea mai mare pentru modelul EGARCH(2,2,1) sub distribuția normală a erorilor.

Pentru a vedea ce model a performat cel mai bine dintre cele 4 am folosit metoda de backtesting în Excel în care am calculat numărul de depășiri ale valorii de risc cu fiecare dintre probabilități (95% și 99%) pentru un orizont de 1 zi în comparație cu randamentele portofoliului din perioada analizată. Rezultatele obținute sunt prezentate în tabelul nr. 10.

Tabel nr.10. Backtesting VaR

Model	GARCH(1,1)T	IGARCH(2,2)T	TGARCH(1,1,1)N	EGARCH(2,2,1)N
Depasiri VaR-1day 95%	16	28	16	17
Interval 5%	(0,25)	(0,25)	(0,25)	(0,25)
Depasiri VaR-1day 99%	8	11	8	11
Interval 1%	(0,5)	(0,5)	(0,5)	(0,5)

Sursa: Prelucrare proprie Excel

Din rezultatele obținute se poate observa că modelele care au oferit cele mai bune rezultate sunt GARCH(1,1) sub distribuția erorilor t-Student și TGARCH(1,1,1) sub distribuția normală a erorilor. 3 modele selectate s-au încadrat în intervalul de încredere de 95%, în schimb VaR estimat cu probabilitatea de 99% prezintă erori, acesta subestimând riscul. Prin urmare este recomandată estimarea VaR pentru portofoliu utilizând modelele GARCH(1,1) sub distribuția erorilor t-Student și TGARCH(1,1,1) sub distribuția normală a erorilor folosind intervalul de încredere de 95%, însă nici celelalte modele nu prezintă diferențe foarte mari.

Concluzii

În această lucrare am realizat o cercetare cu privire la evaluarea riscului pentru un portofoliu diversificat de acțiuni. Această etapă, de evaluare a riscului, reprezintă partea cea mai importantă din managementul riscului pentru orice instituție financiară sau pentru un investitor individual. Pentru început am prezentat în primul capitol stadiul actual al cunoașterii făcând referire la articolele și cărțile studiate. De-a lungul timpului s-au dezvoltat tot mai multe cercetări pe această arie datorită creșterii importanței managementul riscului în instituțiile financiare.

În acest scop am constituit un portofoliu de acțiuni diversificat datorită volatilităților tot mai ridicate de pe piața de capital. Pentru evaluarea riscului acestui portofoliu am folosit metoda cea mai comună de managerii de risc și anume, Value at Risk. În capitolul 2 am prezentat metodologia utilizată și caracteristicile serilor de date. În cadrul metodologiei am prezentat metoda analitică pentru calculul VaR și 4 modele (GARCH, IGARCH, EGARCH și TGARCH) pentru estimarea volatilității portofoliului. Am obținut istoricul prețurilor zilnice pentru cele 3 acțiuni, apoi am folosit logaritmul pentru a determina randamentele portofoliului. Prin prezentarea caracteristicilor serilor de date (nu prezintă autocorelare, apariția fenomenului de volatility clustering, homoscedasticitatea serie și distribuția leptokurtotică) am justificat folosirea modelelor de varianță condiționată pentru calculul VaR. În partea a treia a lucrării am prezentate rezultatele obținute în urma estimării varianței în Eviews. Pentru fiecare model am estimat mai multe ecuații ale varianței sub diferite distribuții ale erorilor (normală, t-student și GED) selectându-le doar pe cele cu coeficienții semnificativi statistic. Diferențierea între modelele selectate am făcut-o cu ajutorul criteriilor informaționale (AIC și SBIC), rezultând în final cele 4 modele de estimare. Pentru calculul valorii la risc am ales un orizont de 10 zile cu probabilitățile de 95% și 99%. Aplicând metoda backtesting-ului am calculat numărul de depășiri VaR cu orizontul 1 zi din perioada analizată față de randamentele portofoliului. Modelele GARCH(1,1) sub distribuția erorilor t-Student și TGARCH(1,1,1) sub distribuția normală a erorilor au oferit cele mai bune rezultate însă estimarea VaR cu o probabilitate de 99% a prezentat erori pentru fiecare model.

În concluzie, este recomandată testarea mai multor modele în vederea evaluării riscului, deoarece o subestimare sau o supraestimare a riscului poate provoca pierderi importante oricăror instituții financiare.

Bibliografie

- [1] Artzner P. F., Delbaen J. Eber J. Heath D. - (1999) “Coherent measures of risk”, *Mathematical Finance*, pg. 203-228
- [2] Codirlaşu A. (2007) – “Modele Value at Risk”, FABBV, ASE București
- [3] Christoffersen (2012) – “Elements of financial risk management”, 2nd ed., Ed. Academic Press
- [4] Hansen, R., Lunde, A. (2001) – “A comparison of volatility models: Does anything beat a GARCH(1,1)?”, *Journal of applied econometrics* 20, pg. 873-889
- [5] Iorgulescu F. (2008) – “Value at Risk: A comparative analysis”, dissertation paper, FABBV, ASE București
- [6] Manașe D., Cuzman I., Fărcaș P. – “Aspecte privind managementul riscului în societățile de investiții financiare, în contextul schimbărilor economice recente”, SIF Banat-Crișana, Arad
- [8] Poon, Granger (2003) – “Forecasting Volatility in Financial Markets” – *Journal of Economic Literature*, Vol 41, No. 2, pg. 478-539
- [9] Stan Georgiana (2015) – “Măsuri ale riscurilor financiar-bancare”, Colecția de working papers “ABC-ul lumii financiare”, FABBV, ASE București

- [10] Trenca I, Pece A, Mișuț I. (2015) – “*The assessment of market risk in the context of the current financial crisis*”, Procedia Economics and Finance 32, pg. 1391 – 1406